

Sistema de control basado en fusión para la navegación autónoma de vehículos

Franco Penizzotto, Orlando Alvarez, Daniel Patiño, and Ricardo Carelli

Instituto de Automática, Universidad Nacional de San Juan
Av. San Martin Oeste 1112, Capital, San Juan, Argentina
{fpenizzotto, dpatino, rcarelli, }@inaut.unsj.com.ar
www.inaut.unsj.edu.ar

Abstract. En este trabajo se propone una fusión de estados obtenidos a partir de dos sensores, odómetro y GPS, funcionando cada uno con su respectivo tiempo de muestreo, pudiendo coincidir o no con el tiempo de muestreo del sistema controlador. Se pretende que un robot móvil navegue en forma autónoma, con alto nivel de robustez, por el centro de corredores formados por plantas de vides o frutales como olivos, o que describa una trayectoria deseada en campo abierto. Se propone utilizar un sensor GPS de bajo costo y un sensor odométrico para calcular los estados requeridos por un controlador de tipo cinemático y no lineal, capaz de cumplir con la tarea deseada. Se utiliza una estructura de Kalman Extendido, basada en el modelo cinemático del robot tipo unicycle, para filtrar y preparar las señales antes de ser fusionadas. También se logra resetear el sensor odométrico a partir de los datos fusionados. El método ha sido probado en experimentación en campo, utilizando el robot Pioneer3AT.

Key words: Agricultura de precisión, robótica móvil, GPS, frutales y agricultura extensiva, fusión de sensores.

1 Introduction

Una tendencia actual en la agricultura mundial es el desarrollo de tecnologías avanzadas para la obtención de grandes producciones de elevada calidad en ambientes lo más naturales posibles, a bajos costos y en tiempos admisibles impuestos por el mercado. Un área de intensa investigación y de interés práctico indudable en la automática es la Robótica. Dentro de esta disciplina un campo de aplicación importante y de reciente crecimiento es el de los robots autónomos, los cuales están generando un impacto creciente en la industria de la producción y en el sector de servicios, al poder actuar en escenarios parcialmente estructurados o variantes en el tiempo, en contraposición de las aplicaciones típicas de la robótica en ambientes industriales especialmente estructurados para su operación. En este marco, se plantea el desarrollo de sistemas avanzados de control y de percepción sensorial que permitan una mayor autonomía de las operaciones agrícolas tales como cosecha, labranza, fumigación, segado, desinfección, supervisión, identificación estructural de cultivos, etc..

Numerosos investigadores han desarrollado métodos de automatización de equipos móviles para su navegación autónoma en entornos agrícolas. Una de las posibilidades se basa en sistemas de referencia fijo, calculando de manera precisa el patrón geométrico del terreno o por enseñanza manual a la máquina. La ruta es seguida utilizando sistemas de posicionamiento global, tales como sistemas GPS, brújulas, y marcas visuales. La planificación preestablecida no está sujeta a modificaciones posteriores, no pudiendo responder a cambios inesperados en el terreno. Trabajos de este tipo se presentan en [6], donde se demuestra el uso de tecnología GPS para encontrar la posición y orientación de un vehículo. Una segunda alternativa a la problemática propuesta, se vale de sensores de posicionamiento relativos, tales como láser, cámaras, odometría, etc., para determinar referencias locales como plantas, líneas de cultivo, etc. y con éstas, generar una ruta a seguir. Esta opción dota de versatilidad y flexibilidad al sistema móvil, dado que admite ciertas modificaciones o diferencias entre cultivos de la misma especie.

Por ejemplo, puede citarse el trabajo de [7], donde un tractor es guiado por una plantación de cítricos mediante el uso de cámaras y también de un sensor láser. Los experimentos realizados, requieren que los límites del sendero sean continuos, como el follaje de los árboles de cítricos. Además, puede citarse el trabajo de [1] donde se exponen métodos de navegación en pasillos continuos basados en líneas de perspectiva, utilizando cámaras.

La referencia [10] propone un sistema para navegación en diversos entornos agrícolas como son las plantaciones de vides o frutales. En el presente trabajo, se pretende robustecer el sistema mediante la redundancia de sensores y además, extender la navegación a entornos de campo abierto. Para ello, se propone un esquema general de múltiples sensores de distintos tiempos de muestreo, con una fusión centralizada a nivel de variables de posicionamiento del móvil respecto de un punto inicial. En este trabajo se presenta la utilización de un sensor GPS y un sensor odométrico. Se propone un método de interpolación de valores de las señales de posicionamiento del GPS. Luego, tras la utilización de Filtros de Kalman Extendidos para cada observación realizada, se fusionan dichos datos, logrando una mejor estimación de los estados y brindando mayor robustez al sistema. Además, se logra corregir el sensor odométrico en cada instante de muestreo. Se define un bloque de generación de referencias para establecer la trayectoria deseada. Luego, un controlador de tipo no lineal basado en cinemática expuesto en [12], se encarga de que el móvil cumpla con el seguimiento de la trayectoria generada.

A futuro, es posible adicionar algoritmos de SLAM en ambiente abiertos para ampliar y mejorar las capacidades del sistema [8]. Además, puede agregarse sensores al sistema para mejorar la estimación y para incrementar la robustez.

La sección 2 esquematiza la propuesta, luego en 3 se define la ley de control. Posteriormente, se explica la lectura y filtrado de los datos. En 7 se muestra la experimentación y finalmente, en 8, se presentan las conclusiones.

2 Planteo de la estrategia

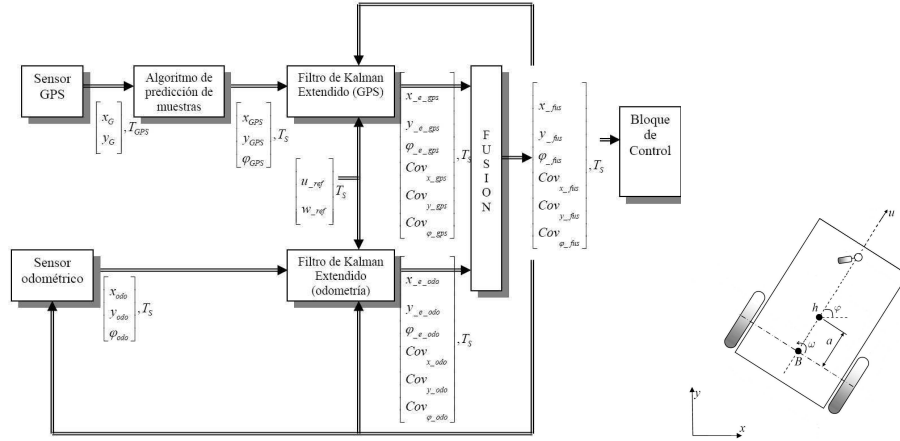


Fig. 1. 1(a):Esquema general de la solución ; 1(b) Modelo del robot uniciclo

La Fig. 1(a) esquematiza los pasos que enmarcan la solución propuesta para la problemática establecida en la introducción. Se necesita calcular en forma robusta los estados que representan la localización del móvil $[x \ y]^T$, los cuales son requeridos por el controlador para ser llevados a los valores deseados que dependen de la trayectoria deseada, generada por el bloque correspondiente. En este trabajo, se filtra la información proveniente de cada sensor con un Filtros de Kalman Extendidos basados en el modelo del robot uniciclo, en todo tiempo de muestreo T_s , obteniéndose según el sensor GPS $[x_{e_{gps}}(t) \ y_{e_{gps}}(t) \ \varphi_{e_{gps}}(t)]^T$ y por otro lado, basándose en el sensor odométrico se obtiene $[x_{e_{odo}}(t) \ y_{e_{odo}}(t) \ \varphi_{e_{gps}}(t)]^T$, más las covarianzas de estas observaciones.

Luego, con los dos vectores de estados estimados obtenidos más las covarianzas correspondientes, se ingresa al bloque de fusión, donde se obtiene consigue un único vector $[x_{fus}(t) \ y_{fus}(t) \ \varphi_{fus}(t)]^T$ el cual ingresa al controlador de tipo no lineal utilizado en [12].

Para que el controlador sea capaz de mantener el móvil en la trayectoria deseada, deberá trabajar a un tiempo de muestreo lo suficientemente chico según las velocidades deseadas definidas. Este tiempo de muestreo de control T_s , es el más chicos de todos los tiempos de los subsistemas de sensado utilizado. Los filtros de Kalman deben actualizarse a la misma frecuencia que el controlador, por lo tanto, los algoritmos de Kalman se actualiza en cada T_s . El tiempo de muestreo del sensor GPS $T_{s_{GPS}}$ depende del sensor utilizado y además, en momentos donde el GPS pierde señal, el $T_{s_{GPS}}$ se incrementa en distintas proporciones. Por ello, es necesario implementar alguna estrategia para solucionar este inconveniente.

3 Controlador

3.1 Modelo cinemático de estados del robot unicycle

De la figura 1(b):

Las ecuaciones cinemáticas del error se expresan como:

$$\begin{cases} \dot{\tilde{x}} = u_{ref} \cos \varphi - a\omega_{ref} \sin \varphi \\ \dot{\tilde{y}} = u_{ref} \sin \varphi + a\omega_{ref} \cos \varphi \\ \dot{\tilde{\varphi}} = \omega_{ref} \end{cases} \quad (1)$$

La salida del sistema es formada por las coordenadas del punto de interés $h = [x(t) \ y]^T$.

Las variables de estado del sistema son $[x(t) \ y \ \varphi]^T$. Como el modelo es cinemático, se considera que $u_{ref} = u$ y $\omega_{ref} = \omega$. La dinámica que genera la planta frente a los cambios en la referencia $[u_{ref} \ \omega_{ref}]^T$, no se refleja en este modelo de estado y por ello, en la ecuación 1 se utilizan las velocidades de referencias en lugar de las velocidades realmente alcanzadas por el móvil.

3.2 Ley de control

El controlador de tipo no lineal utilizado fue implementado en [12]. El robot móvil recibe señales de velocidad lineal y de velocidad angular.

El objetivo de control se define como:

$$[\tilde{x}(t) \ \tilde{y}(t)]^T \rightarrow 0 \quad (2)$$

donde $\tilde{x}(t)$ y $\tilde{y}(t)$ representan los errores de posición en las coordenadas del plano. Con el cumplimiento del objetivo de control, el móvil se encontrará siguiendo la trayectoria deseada, a velocidad definida.

Por lo expuesto, se tiene que:

$$h = \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} \cos \varphi & -a \sin \varphi \\ \sin \varphi & a \cos \varphi \end{bmatrix} \begin{bmatrix} u \\ \omega \end{bmatrix} = A \begin{bmatrix} u \\ \omega \end{bmatrix} \quad (3)$$

La ley de control propuesta es

$$\begin{bmatrix} u_{ref} \\ \omega_{ref} \end{bmatrix} = \begin{bmatrix} \cos \varphi & \sin \varphi \\ -\frac{1}{a} \sin \varphi & \frac{1}{a} \cos \varphi \end{bmatrix} \begin{bmatrix} \dot{x}_d + l_x \tanh\left(\frac{k_x}{l_x} \tilde{x}\right) \\ \dot{y}_d + l_y \tanh\left(\frac{k_y}{l_y} \tilde{y}\right) \end{bmatrix} \quad (4)$$

Donde $\tilde{x} = x_d - x$ y $\tilde{y} = y_d - y$ son los errores actuales de posición del punto de interés, en las coordenadas X e Y respectivamente. $k_x > 0$ y $k_y > 0$ son ganancias del controlador, $l_x \in \Re$ y $l_y \in \Re$ son constantes de saturación, x e y son las coordenadas actuales sensadas del punto de interés y x_d e y_d las coordenadas de referencia para el punto de interés.

La estabilidad del controlador fue demostrada en [12].

El bloque de control, antes de aplicar la ley de control, traslada al punto de interés las coordenadas de posición del robot obtenidas tras la fusión de los

estados, para luego obtener los errores de posición correspondientes al punto de interés. Para ello, se utiliza la siguiente expresión:

$$\begin{aligned} x &= x_{fus} + a \cos \varphi & ; & \quad \dot{x} = u \cos \varphi - a \omega \sin \varphi \\ y &= y_{fus} + a \sin \varphi & ; & \quad \dot{y} = u \sin \varphi - a \omega \cos \varphi \end{aligned} \quad (5)$$

4 Estimación de señal del GPS entre lecturas

Todos los sensores GPS entregan localización global. Para el caso de la fusión de datos, es necesario llevar esta localización al mismo sistema absoluto del sensor odométrico. Para estimar el ángulo entre el eje del sistema GPS y el de la tarea, se toman las coordenadas GPS del punto inicial respecto del plano de la tarea, luego alejada sobre el eje x y se calcula el ángulo del vector resultante de la resta entre estos dos vectores. Posteriormente, cada vector posición sensado por el GPS es rotado con una matriz de rotación que es función del ángulo calculado.

Para facilitar y hacer robusta la implementación del filtro de Kalman y fusión para la obtención de la localización, se propone estimar posiciones del GPS aun cuando este no actualice su registro de mediciones, ya sea porque el tiempo de muestreo es superior al utilizado en el subsistema de observación o porque perdió señal momentáneamente. Para ello, considerando que esto se aplicará por pocos pasos de muestreo, se aplica un estrategia basada en modelo. Con las velocidades de referencia, la localización anterior entregada por ese bloque sensor y el modelo discreto del robot, se obtiene la nueva localización estimada del sensor GPS para ese instante de muestreo.

$$\begin{cases} x_{gps}(k) = T_s u_{ref}(k-1) \cos \varphi(k-1) + x_{gps}(k-1) \\ y_{gps}(k) = T_s u_{ref}(k-1) \sin \varphi(k-1) + y_{gps}(k-1) \end{cases} \quad (6)$$

Luego, el modelo de estados discreto utilizado en 6 es explicado en detalle en la sección 5.

5 Filtrado

Uno de los aportes de este trabajo se basa en el agregado de información respecto del modelo para mejorar el cálculo de los errores sensados (estados del modelo cinemático planteado, $[\tilde{x} \ \tilde{y}]$). Para ello, se utilizó un estructura de filtrado de Kalman extendido dado que el modelo de estados es no lineal.

5.1 Ecuaciones del Filtro de Kalman Extendido

La referencia [9] presenta la extensión del filtro de Kalman aplicable a modelos de estados lineales, a esta estructura llamada Filtro de Kalman Extendido que es aplicable a sistemas de estados no lineales, como es el caso planteado en este trabajo.

Modelos discretos del sistema El sistema de estados puede expresarse como $x(k) = f(x(k-1), u(k-1), (k-1)) + w(k)$

donde $x(k-1)$ es el vector de estados y $u(k-1)$ es el vector de entradas conocido, ambos en el instante de tiempo $k-1$. Los vectores $x(k)$ y $w(k)$ representan el vector de estados y el vector de ruido aditivo del proceso respectivamente, ambos en k . $f(\cdot)$ es la función de transición de estados no lineal.

La observación de los estados, considerando el caso más general de sensado no lineal, es $z(k) = h(x(k), (k)) + v(k)$

donde $z(k)$ es el vector de observaciones realizadas en el instante k , $x(k)$ es el vector de estados en k , $v(k)$ es el ruido aditivo de la observación y $h(\cdot)$ es el modelo de la observación no lineal que mapea de los estados actuales a observaciones.

Se asume que ambos ruidos $w(k)$ y $v(k)$ son gaussianos aditivos y lineales, no correlacionados temporalmente y con media cero; es decir que $E[w(k)] = E[v(k)] = 0$

con las correspondientes covarianzas dadas por $E[w(i)w^T(j)] = \delta_{ij}Q(i)$; $E[v(i)v^T(j)] = \delta_{ij}R(i)$

También se asume que el ruido del proceso y el de la medición, no son correlacionados, $E[w(i)v^T(j)] = 0$

Algoritmo EKF Cualquier implementación del filtro de Kalman consta de una *inicialización, predicción, observación y estimación*, donde la inicialización se realiza solo una vez, al comienzo, y la observación corresponde a la lectura de la medición a ser filtrada.

En el algoritmo de EKF (Extended Kalman Fiter) las dos etapas recursivas a programar son descritas por las siguientes expresiones:

Definiendo que $\nabla f_x(k)$ y $\nabla h_x(k)$ son los jacobianos de $f_x(k)$ y de $h_x(k)$ respectivamente y teniendo en cuenta las matrices Q y R definidas anteriormente, se tiene que:

Predicción: La estimación del estado y de las covarianzas en el instante k del vector de estados realizada en $k-1$ es

$$\hat{x}(k|k-1) = f(\hat{x}(k-1), u(k-1), (k-1))$$

$$P(k|k-1) = \nabla f_x(k) P(k-1|k-1) \nabla f_x^T(k) + Q(k-1)$$

Estimación: La estimación del estado y de las covarianzas en el instante k del vector de estados basándose en valores de k es

$$\hat{x}(k|k) = \hat{x}(k|k-1) + W(k) z(k) - W(k) h(\hat{x}(k|k-1))$$

$$P(k|k) = P(k|k-1) - W(k) S(k) W^T(k)$$

Las matrices de ganancia y covarianza de innovación vienen dadas por

$$W(k) = P(k|k-1) \nabla h_x^T(k) S^{-1}(k)$$

$$S(k) = \nabla h_x(k) P(k|k-1) \nabla h_x^T(k) + R(k)$$

Por las ecuaciones expuestas, vemos que la estimación de los estados se realiza con el modelo no lineal del sistema, pero el cálculo de la covarianza se realiza con el jacobiano, es decir, se utiliza el sistema linealizado.

5.2 Ecuaciones discretas del modelo para el filtro

En adelante y en cuanto las ecuaciones consideradas para los filtros y fusión, se considera el punto de interés con $a = 0$, es decir, coincidente con el punto central del eje del móvil. Luego, como se mencionó en la sección 3, las coordenadas estimadas del robot obtenidas con la fusión, serán desplazadas al punto de interés antes de calcular los errores de posición que deben ser llevados a 0 por el controlador.

Modelo discreto de estados para el robot unicycle Discretizando la ecuación 1 (con $a = 0$), se llega a las ecuaciones del modelo de estados discreto

$$\begin{cases} x(k) = T_s u(k-1) \cos \varphi(k-1) + \tilde{x}(k-1) \\ y(k) = T_s u(k-1) \sin \varphi(k-1) + \tilde{y}(k-1) \\ \varphi(k) = T_s w(k-1) + \tilde{\varphi}(k-1) \end{cases} \quad (7)$$

El modelo de la observación correspondiente para cada filtro es:

$$\begin{cases} z_x(k) = x_{gps}(k) \\ z_y(k) = y_{gps}(k) \\ z_\varphi(k) = \varphi_{gps}(k) \end{cases} ; \begin{cases} z_x(k) = x_{odo}(k) \\ z_y(k) = y_{odo}(k) \\ z_\varphi(k) = \varphi_{odo}(k) \end{cases} \quad (8)$$

Puede notarse que por las expresiones 7 y 8, se tienen un casos de sistema de **estados no lineal** con **observación lineal**.

Funciones de transición y Jacobianos La función de transición de estados $f(\cdot)$, para el modelo de estados planteado se describe como

$$f(\cdot) = \begin{bmatrix} x(k) \\ y(k) \\ \varphi(k) \end{bmatrix} = \begin{bmatrix} T_s u(k-1) \cos \varphi(k-1) + x(k-1) \\ T_s u(k-1) \sin \varphi(k-1) + y(k-1) \\ T_s w(k-1) + \varphi(k-1) \end{bmatrix} \quad (9)$$

La expresión del jacobiano de la función de transición de los estados es:

$$\nabla f_x(k) = \begin{bmatrix} \frac{\partial f_1}{\partial x} & \frac{\partial f_1}{\partial y} & \frac{\partial f_1}{\partial \varphi} \\ \frac{\partial f_2}{\partial x} & \frac{\partial f_2}{\partial y} & \frac{\partial f_2}{\partial \varphi} \\ \frac{\partial f_3}{\partial x} & \frac{\partial f_3}{\partial y} & \frac{\partial f_3}{\partial \varphi} \end{bmatrix} ; \nabla f_x(k) = \begin{bmatrix} 1 & 0 & -T_s u_{ref}(k-1) \sin \varphi(k-1) \\ 0 & 1 & T_s u_{ref}(k-1) \cos \varphi(k-1) \\ 0 & 0 & 1 \end{bmatrix} \quad (10)$$

Por otro lado, como el modelo de la observación es lineal,

$$h(\hat{x}(k)) = H\hat{x}(k) \quad ; \quad \nabla h_x(k) = H \quad ; \quad H_{gps} = H_{odo} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (11)$$

Calibración del filtro La matriz de covarianza del error de medición R y la de ruido del proceso Q , se obtienen como $R(k) = \text{diag}\{\sigma_{r.m(\bar{x})}^2 ; \sigma_{r.m(\bar{y})}^2\}$ y $Q(k) = \text{diag}\{\sigma_{r.p(\bar{x})}^2 ; \sigma_{r.p(\bar{y})}^2\}$ donde $\sigma_{r.m}$ son desviaciones estándares debido al ruido de la medición y $\sigma_{r.p}$ al ruido del proceso, ambos asociados a cada estado. En este caso, los σ se tomaron constantes. Los valores de inicialización se determinan por experimentación.

6 Fusión

De la referencia [11] donde se detalla la fusión de dos mediciones estimadas con sus respectivas varianzas, realizadas sobre las mismas variables de estado de un sistema, se extraen las expresiones correspondientes para el cálculo del valor estimado del vector de estados y también para el cálculo de la varianza asociada al valor obtenido. Se aplica al caso particular de este trabajo, tomando el estado x , se obtienen las siguientes expresiones.

$$x_{fus} = \frac{Cov_{x.gps}}{Cov_{x.gps} + Cov_{x.odo}} x_{odo} + \frac{Cov_{x.odo}}{Cov_{x.gps} + Cov_{x.odo}} x_{gps} \quad (12)$$

$$Cov_{x.fus} = \frac{Cov_{x.gps} Cov_{x.odo}}{Cov_{x.gps} + Cov_{x.odo}} \quad (13)$$

Luego esto se extiende a los demás estados del sistema. Se observa de la Ec. 12 que si la confianza en la medición del estado x_{gps} es infinita, es decir, $Cov_{x.gps} \rightarrow 0$, entonces, $x_{fus} = x_{gps}$. Lo mismo ocurre para el otro estado.

Además, puede notarse en la Ec. 13, que si ambas covarianzas son iguales, la covarianza final es la mitad de estas.

7 Experimentación

En la figura 2 se muestra el desempeño del sistema. En la 2(a) (a), se coloca la trayectoria realizada por el robot considerando el punto de interés desplazado del centro. Además, se muestran los perfiles de posición, velocidad y aceleración, para cada estado x e y del sistema. En la 2(b) se presentan las mediciones realizadas por los sensores (rojo - odometría ; azul - GPS) y las respectivas observaciones realizadas por cada filtro.

El controlador es capaz de hacer que el robot siga la trayectoria deseada, según la información de la fusión. Cada 20 pasos de muestreo, el sensor odométrico es inicializado al valor de la posición determinada por la fusión en ese instante.

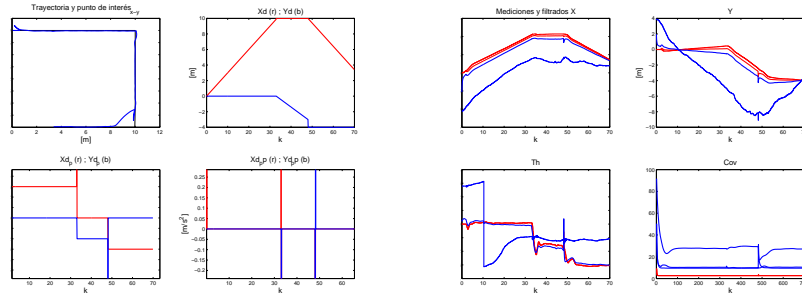


Fig. 2. Resultados experimentales. 2(a): Trayectoria deseada y salida de interés; 2(b): Estados medidos y filtrados, covarianzas

La performance del filtro aplicado a la estimación de la observación realizada por el sensor GPS mejora notablemente la localización del móvil. La localización del robot en los ejes de la tarea, además del error de medición, es afectada por errores en la determinación del ángulo de desplazamiento γ entre el sistema coordenado del GPS y el de la tarea.

La covarianza de la fusión es menor que las covarianzas individuales de cada sensor. Como el experimento se realizó en pocos metros, no se nota el incremento del error en la señal sensada con odometría, y por ende, no se distingue la reducción de la covarianza al fusionar la señal.

8 Conclusiones

En este trabajo, se ha propuesto un método generalizado para la navegación plantaciones semi-estructuradas o de tipo extensivas, proponiendo un algoritmo de cálculo de la posición de un punto de interés respecto del móvil, basado en odometría y en GPS, con posibilidad de utilizar altos tiempos de muestreo requeridos por tareas de altas velocidades de labranza.

Este sistema presenta ventajas respecto a los sistemas basados en visión, que requieren del conocimiento de los colores del terreno para su diseño. Además, se presenta un esquema generalizado donde, por un lado se estiman las mediciones de los sensores cuando no hay señales disponibles y por el otro se utiliza una estrategia de fusión de sensores expansible a N sensores. Esto permitió el funcionamiento de cada sensor en forma independientemente y con tiempos de muestreo mayores al tiempo de muestreo del controlador.

La incorporación del control de trayectoria facilita la aplicación a diversas tareas de labranza, fumigación y cosecha en función de la estructuración de la plantación y de las dimensiones de la máquina.

Los experimentos en campo verifican la robustez, versatilidad y estabilidad del sistema. En trabajos futuros, deberá adicionarse al controlador, la capacidad de evasión de obstáculos y fusionar con otros métodos de localización.

Agradecimientos

Este trabajo fue financiado por la Agencia Nacional para la Promoción Científica y Tecnológica (ANPCyT) bajo subsidio PICT/04 21592 y PICT/05 35398. Además, PICT03 Redes 342.

References

1. Carelli, R., R. Kelli, O.H. Nasisi, C. Soria y V. Mut, "Control based on perspective lines of a non-holonomic mobile robot with camera-on-board," *International Journal of Control*, Lugar donde se realizó, 362-371(2006).
2. Carelli, R. , E. Oliveira Freire, "Corridor navigation and wall-following stable control for sonar-based mobile robots," *Robotics and Autonomous Systems*, **45**, 235-247 (2003).
3. Garcia Pereira, F., *Navegacao e Desvio de Obstáculos Usando um Robo Móvrl Dotado de Sensor de Varredura Laser*, Programa de Pós-Graduacao em Engenharia Elétrica - Iniversidades Federal do Espírito Santo, Vitória (2006).
4. Liberzon, D. , A.S. Morse, *Benchmark problems in stability and design of switched systems*, Yale University, New Haven (1999).
5. Ortiz, J.M. , M. Olivares, "A Vision Based Navigation System for an Agricultural Field Robot," *3rd IEEE Latin America Robotics Symposium*, Santiago de Chile, Código de art. 86 (2006).
6. O'Connor, M., T. Bell, G. Elkaim, B. Parkinson, "Automatic Steering of Farm Vehicles Using GPS," *In Proc. of the 3rd Int. Conf. on Precision Agriculture*, (1996).
7. Subramanian, V., T.F. Burks y A.A. Arroyo "Development of machine vision and laser radar based autonomous vehicle guidance systems for citrus grove navigation," *Computers and Electronics in Agriculture*, **53**, 130-143 (2006).
8. Guivant, J., F.R. Masson y E.M. Nebot "Simultaneous localization and map building using natural features and absolute information," *Elsevier Science B.V.*, **40**, 79-90 (2002).
9. Mutambara, A.G.O. "Decentralized estimation and control for multisensor systems," *CRC Press LLC*, , (1998).
10. Penizzotto, F. and Teodovich, L. and Carelli, Patiño, D. "Sistema de control basado en láser para la navegación autónoma de vehículos en plantaciones de viñedos y frutales," *XII Reunión de Trabajo en Procesamiento de la Información y Control*, , (2007).
11. Welling, M. . "The Kalman Filter," *Technical Notes - California Institute of Technology*, .
12. Martins, F. N. , Celeste, W. C. , Carelli, R. , Sarcinelli-Filho, M. , Bastos-Filho, T.F. "An Adaptive Dynamic Controller for Autonomous Mobile Robot Trajectory Tracking," *Control Engineering Practice*, **10.1016/j.conengprac.2008.03.004**, (2008).